

基于深度学习的道路标线自动提取与分类方法

黄刚^{1,2*}, 刘先林³

¹首都师范大学资源环境与旅游学院, 北京 100048;

²北京四维远见信息技术有限公司, 北京 100070;

³中国测绘科学研究院, 北京 100830

摘要 道路标线提取与分类是智慧城市建设中需要解决的关键技术之一,也是智能驾驶亟待解决的技术难题。提出了一种基于深度学习的道路标线自动提取与分类方法,通过移动窗口法结合相邻扫描线拓扑关系进行地面点云的提取,并生成强度图像,基于深度学习方法实现道路标线的自动提取与分类,并利用 KD 树聚类分割算法结合矢量化方案实现道路标线的矢量化。基于实验数据对该方法进行验证分析,结果表明,使用该方法进行自动提取与分类的精度和 F_{score} 分别为 92.59% 和 90.15%,证明了该方法的可行性和准确性。该方法为道路标线的自动提取提供了新思路,使道路标线提取工作变得更准确、高效,提升了道路标线获取与分类的智能化程度。

关键词 遥感;深度学习;道路标线;自动提取;移动测量系统

中图分类号 O436

文献标识码 A

doi: 10.3788/CJL201946.0804002

Automatic Extraction and Classification of Road Markings Based on Deep Learning

Huang Gang^{1,2*}, Liu Xianlin³

¹College of Resource Environment and Tourism, Capital Normal University, Beijing 100048, China;

²Beijing GEO-Vision Tech. Co., Ltd., Beijing 100070, China;

³Chinese Academy of Surveying & Mapping, Beijing 100830, China

Abstract Extraction and classification of road markings are two key technologies to be solved in the construction of an intelligent city and urgent technical problems that must be solved for intelligent driving. Therefore, herein, we propose a method of automatic extraction and classification for road markings based on deep learning. First, the ground point clouds are extracted through the moving-window method combined with the topological relations of adjacent scanning lines, and then the intensity images are generated. Automatic road-marking extraction and classification are realized based on the deep learning method. Road-marking vectorization is performed using the KD tree clustering algorithm and the vectorization scheme. The proposed method is analyzed based on the obtained experimental data. Results show that the precision and F_{score} of the automatic road-marking extraction and classification reach 92.59% and 90.15%, respectively, proving the feasibility and accuracy of this method. Thus, the proposed method provides a new idea for automatic road-marking extraction and improves its accuracy, efficiency, and intelligent degree of road-marking acquisition and classification.

Key words remote sensing; deep learning; road marking; automatic extraction; mobile measurement system

OCIS codes 280.4750; 100.4996; 280.3640

1 引言

道路标线是重要的交通标志,具有分离道路区

域、规定行进走向、为行人提供引导信息等作用^[1-2]。随着智能驾驶技术的进步,对路面信息的需求也逐渐加大,道路标线信息作为导航地图的核心要素之

收稿日期: 2019-02-26; 修回日期: 2019-03-22; 录用日期: 2019-04-02

基金项目: 国家重点研发计划(2018YFF0215303, 2017YFB0503004)、高分辨率对地观测系统重大专项(42-Y2-0A14-9001-17/18)

* E-mail: hgminisar@163.com

一,其自动感知与识别成为国内外研究的热点。获取道路标线信息的传统方式是使用全球定位系统(GPS)或全站仪进行全野外测量,该种方式采集效率低、人员投入大、现实性差,难以满足当前智能驾驶快速、高效的需求。近年来,有研究人员基于高精度图像和视频来提取道路标线^[3-5],但受光照影响,提取效果对影像质量的要求较高。车载移动测量系统是一种以车辆为搭载平台的多波段三维信息采集系统,主要集成了全景相机、激光扫描仪、惯性测量单元、GPS等传感器,可以快速获取道路及周边地物的海量高精度实景三维激光点云和影像数据,成为智能驾驶不可或缺的数据支撑来源之一,同时也为道路标线的自动提取提供了新方法^[6-10]。

目前,国内外研究人员已经开展了基于移动LiDAR点云数据的道路标线提取方法研究。方莉娜^[11]利用标线多尺度分割方法,将标线点从点云中分离出来,然后结合强度图像,融合标线的几何特征和语义信息,实现了标线的快速提取;Yan等^[12]基于移动激光扫描系统数据,在点云强度图像中使用动态中值滤波来降低强度噪声,利用边缘检测和边缘约束方法(EDEC)提取道路标线的点云,最后基于分割和维数特征信息剔除伪道路标线点;Soilán等^[13]基于道路标线的反射特性进行点云滤波,并制作二进制栅格图像,通过特征提取和神经网络方法进行道路标线的提取和分类。以上方法大多是基于道路标线的某类或某几类特征进行提取的,而且需要一定的先验知识,对强度较低的道路标线提取效果较差,当标线和路面强度差异较小时,容易出现漏提或错提现象。深度学习是一种自动表征的学习方法,能够在不需要人工定义特征的前提下,通过建立、模拟人脑神经结构进行分析学习,并解释数据。与人工规则构造特征的传统方法相比,利用大数据来学习特征,能够更准确地刻画数据的内在信息,最终提升分类或预测的准确性^[14-16]。Wen等^[17]基于三维移动激光点云数据,使用U-net模型进行点云分割,随后利用多尺度聚类结合卷积神经网络(CNN)进行点云分类,最后基于生成对抗网络对结果进行完善,对道路标线提取与分类的深度学习方法进行了探索。

本文基于DeepLab V3+模型的深度学习方法,实现了车载移动测量系统数据中道路标线的自动提取与分类,并结合点云聚类分割与矢量化方案将自动提取结果进行矢量化。本方法为道路标线的自动提取提供了新思路,使道路标线提取工作变得更准

确、高效,为智能驾驶和标线维护提供了有效的技术支持。

2 车载移动测量系统

车载移动测量系统集成了激光扫描仪、CCD相机、定位定姿系统(POS)、里程计等传感器,由控制单元、数据采集单元和数据处理软件构成,可实现多波段、高精度、高密度三维信息的快速获取及处理,其结构如图1所示。基于获取道路路面信息的需要,将激光扫描仪倾斜向下安放,以获取道路的高密度点云数据,并配备4台CCD相机分别获取平台四侧的影像数据。由于不同的传感器在平台上的安装位置不同,数据采集的参考坐标系也不同,需要在高精度POS数据的辅助下获取定位定姿数据,以完成对获取数据的轨迹解算、检校及坐标转换,最终提供高精度的道路三维坐标信息。




图1 车载移动测量系统

Fig. 1 Vehicle-borne mobile measurement system

3 道路标线的自动提取与分类方法

基于深度学习的道路标线自动提取与分类方法主要包括:对车载移动测量系统获取的原始数据进行预处理,获取地面点云并生成强度图像;使用标记后的强度图像训练语义分割模型,并使用训练后的模型进行道路标线的提取与分类;结合点云聚类分割与矢量化方案将自动提取结果进行矢量化。该方法的技术流程如图2所示。

3.1 原始数据预处理

车载移动测量系统获取的原始数据需要通过激光雷达厂家提供的数据处理软件来获取初始值,然后结合组合导航数据,通过移动测量系统的定位原理,解算出高精度的点云数据。为达到道路标线自动提取的目的,还需要对解算后的点云数据进行道路地面点的提取,并生成强度图像。

车载移动测量系统采集的激光点云数据中包含了道路、树木、建筑物、车辆及行人等,若不进行道路

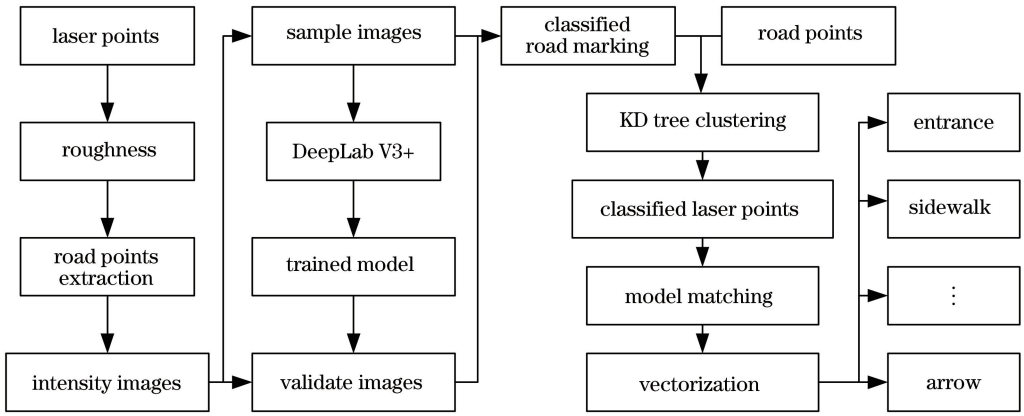


图 2 道路标线自动提取与分类方法流程图

Fig. 2 Flow chart of automatic extraction and classification for road markings

点云的提取,就会增大道路标线自动提取的难度。采用移动窗口法结合相邻扫描线拓扑关系可以在完全不考虑以往算法中所涉及的角度、坡度、点云密度等相关阈值的前提下,以地面粗糙度为准则精确地提取地面点,故采用该方法从点云数据中提取地面点^[18],可以有效减少数据量,并消除附属设施点云对道路标线提取结果的影响。统计提取的地面点云的三维空间坐标($X_{\min}, Y_{\min}, Z_{\min}, X_{\max}, Y_{\max}, Z_{\max}$),设置地面分辨率为 R_{GSD} ,并向 XOY 平面投影,得到的格网大小(W, L)为

$$\begin{cases} W = (X_{\max} - X_{\min}) / R_{\text{GSD}} \\ L = (Y_{\max} - Y_{\min}) / R_{\text{GSD}} \end{cases} \quad (1)$$

上述格网内某一格网(i, j)的特征值 F_{ij} ,可由投影到该点的 n_{ij} 个激光点的平面分布、高程起伏、点云密度等共同决定,其中平面分布权重与该点到中心点的距离成反比,高程起伏权重与扫描点的高程值成正比。第 k 个激光点的权值计算公式如下

$$\begin{cases} W_{ijk}^{XY} = \sqrt{2} R_{\text{GSD}} / D_{ij}^k \\ W_{ijk}^H = (Z_{ij}^k - Z_{\min}) (h_{ij(\min)} - Z_{\min}) / (Z_{\max} - h_{ij(\max)}) \\ W_{ijk} = \alpha W_{ijk}^{XY} + \beta W_{ijk}^H \end{cases} \quad (2)$$

式中: W_{ijk}^{XY} 、 W_{ijk}^H 分别为该激光点的平面权值和高程权值; D_{ij}^k 为该激光点与格网中心点的平面距离; Z_{ij}^k 为该激光点的高程值; $h_{ij(\min)}$ 、 $h_{ij(\max)}$ 分别为格网内激光点的最小与最大高程值; W_{ijk} 为该激光点的总权值; α 、 β 分别为平面与高程的权值系数,且二者的和为1。依据(2)式求得格网内每个激光点的总权值后,即可计算格网的特征值,计算公式如下

$$F_{ij} = \frac{\sum_{k=1}^{n_{ij}} (W_{ijk} I_{ijk})}{\sum_{k=1}^{n_{ij}} W_{ijk}} \quad (3)$$

式中: I_{ijk} 为格网(i, j)内第 k 个激光点的强度特征

值。随后,将计算所得的特征值归一化到 $[0, 255]$ 灰度空间范围内,得到强度特征图像。

3.2 道路标线提取与分类

语义分割是计算机视觉的基本任务,即对视觉输入分为不同的语义可解释类别,以便实现对图像的逐像素分类。现有的深度学习语义分割结构主要有全卷积网络(FCN)、SegNet、RefineNet、PSPNet、全局卷积网络(GCN)及DeepLab系列等。DeepLab系列是谷歌提出的语义分割模型,它改进了卷积神经网络的特征提取器,能更好地对物体建模,对上下文信息的理解也较为准确。

DeepLab V3+网络是目前DeepLab系列中最新的、执行效果最好的语义图像分割模型,可通过空洞卷积平衡精度和耗时,提高编码器-解码器网络的运行速率和稳健性,在PASCAL VOC2012数据集上的分割均交并比达到了89.0%,是现有语义分割模型中性能最高的。DeepLab V3+模型采用编码器-解码器结构,如图3所示(Conv表示卷积),能够获得锐利的种类边界。编码器模块通过在多个尺度上应用扩散卷积来编码多尺度的上下文信息,从而可以简单地沿着物体的边界细化分割结果^[19]。解码时,将编码特征进行以4为因子的双线性上采样,然后连接从主干网络中输出的对应的具有相同空间分辨率的低维特征。由于对应的低维特征一般包含较多的信道,可能会超过输出编码的特征,导致训练难度较大,故在连接操作前,采用 1×1 卷积对低维特征进行处理,以减少信道数。连接处理后,采用 3×3 卷积和以4为因子的双线性上采样来改善特征。

本研究以道路标线强度特征图像为基准,采用基于DeepLab V3+网络^[19-20]的语义分割方法进行自动提取和分类。道路标线语义分割主要包括样本

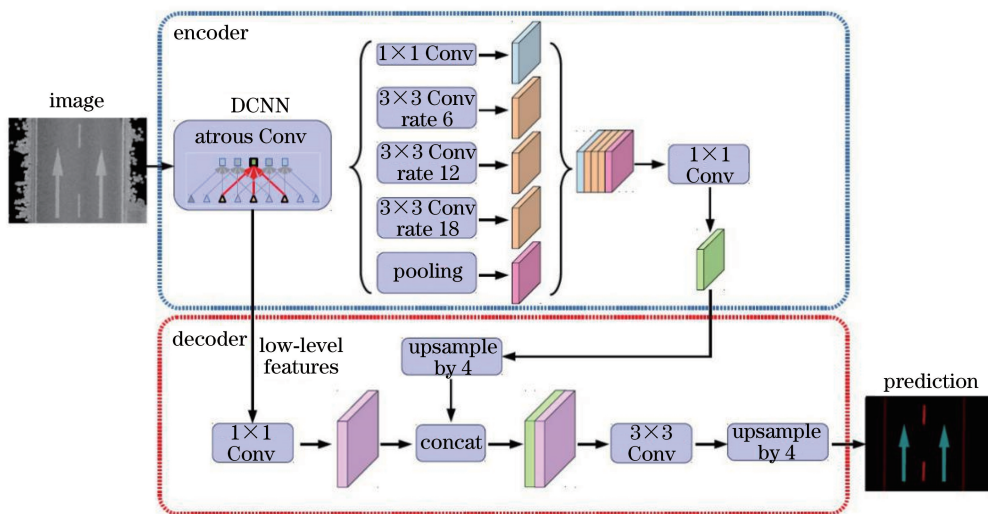


图 3 DeepLab V3+ 结构图^[17]

Fig. 3 Structure of Deeplab V3+

制作、模型训练、道路标线提取和分类等关键步骤。

在样本制作时,使用 Labelme 对道路标线强度特征图进行标记,根据需要对每个像素分别赋予不同类别的标记和颜色,制作样本集和验证集标记图。由于原始图像尺寸不一,需要进行裁剪处理,将所有图像归一化到同一尺寸进行训练和验证。

在进行模型训练时,要根据实际要求制作指引文件,将训练集和验证集影像分别放在两个文件夹,并将文件名分别存入训练和验证文本中,同时应保证标记图和原图一一对应,且文件名相同。将上述制作完成的数据集转换为 TFRecord 格式,并修改训练脚本,在分割数据集配置文件中加入个人数据集描述配置,并注册数据集。综合考虑样本特征和硬件情况,合理设置训练参数,主要修改训练步数、带孔卷积感受视野大小、裁剪训练图像尺寸、批处理参数、预训练模型和文件路径等。由于本研究数据集与 DeepLab V3+ 标准数据集存在差异,且种类数不同,故在模型训练时不使用预训练权重,且仅加载训练后的非归一化对数概率参数。针对数据不平衡现象,统计样本中目标分类的像素占比情况,在训练配置文件中修改各类训练的权重。

训练完成后,对训练模型进行可视化和评估,对应的可视化及评估尺寸参数设置为原图尺寸,达到预期要求后,将训练后的模型导出,并使用该模型对验证集样本进行处理,完成道路标线的提取与分类,最后依据结果统计验证集的分类精度。

3.3 道路标线矢量化

KD 树聚类算法能根据较少的已知聚类样本的类别对树进行剪枝,确定部分样本的分类。为克服

少量样本聚类的不准确性,该算法本身具有优化迭代功能,在已经求得的聚类上再次进行迭代,并对剪枝进行修正,以确定部分样本的聚类,优化初始监督学习样本的分类。由于只针对部分小样本,所以可以降低总的聚类时间复杂度^[21]。本研究基于自动提取与分类结果,利用 KD 树点云聚类分割算法来获取每个对象的激光点集,进而实现道路标识线的点云对象化。在进行点云聚类分割时,用 KD 树对点云进行划分,获得不同点团之间的邻接关系,再根据距离约束因子进行聚类分析,获取相应对象的激光点云。将获取的对象化点云与设计的标线模板进行匹配,获取相应的标准化道路标线模型,然后针对不同类型标线的特点和精度要求,设计不同的矢量化方案,实现道路标线矢量化。例如:对于车道线和停止线,以一定间隔取中线,得到多段线形式的矢量结果;对于箭头标线,通过点云模板匹配方法进行定位和矢量化;对于人行道和网状线,通过获取外轮廓范围并进行内部填充的方式进行矢量化。矢量化后的道路标线具有三维坐标,可以方便地查询、测量和管理,为道路标线智能化和智慧城市建设和提供了有效的技术支撑。

4 实验分析

实验数据采用 SSW 车载移动测量系统采集的深圳市道路数据,使用 Riegl VUX-1HA 激光扫描仪进行数据的采集,其参数设置如下:视场角为 360° ,点频为 1017 kHz,线频为 250 Hz,激光发散度为 0.5 mrad,测量精度为 5 mm,采用四回波采集模式。依据项目需求,为避免车速过快导致的激光点

云过于稀疏影响到数据的精度,将数据采集过程中的车速限定在 40 km/h 左右。

对获取的点云数据进行预处理,获取道路的点云数据,并使用 3.1 节的方法制作强度特征图像,其地面分辨率为 0.2 m,结果如图 4(a)所示。使用 Labelme 样本制作软件,对强度特征图进行标记,制作训练样本,标记结果如图 4(b)所示。基于道路标线的不同表现形式,将其分为纵向减速带、出入口标志线、网状线、人行道、导流带、各种箭头、横向减速带、实线、虚线、符号(包括文字、菱形标志、三角形标志)10 类,并对它们分别赋予不同的类别标记和颜色,以便进行分类提取。如果训练数据量过少,就容易产生训练结果不收敛和过拟合现象,故对实验数据进行样本增强,对每一幅图像分别进行角度为 -30° 、 -15° 、 $+30^\circ$ 和 $+15^\circ$ 的旋转,增加训练样本的数量。

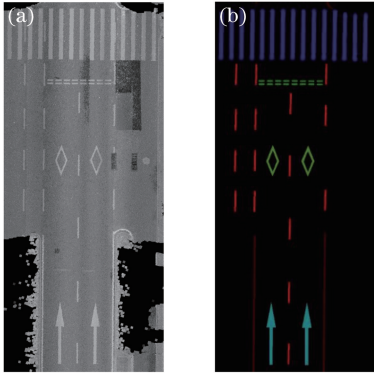


图 4 样本制作。(a)强度特征图像;(b)标记图

Fig. 4 Sample production. (a) Intensity characteristic image; (b) labeled image

由于每一幅从三维激光点云转换生成的强度特征图像大小不同,为统一尺寸,对每张强度特征图像进行分块处理,分块后的图像大小为 1024 pixel \times 1024 pixel,相邻图像之间保留 200 pixel 的重叠区域,对应的路面实际长度为 4 m,分块后样本图像的数量为 8008 幅。基于以上样本图像进行模型训练,训练过程中如果迭代次数或误差达到阈值,则迭代终止。训练时,截取图像的尺寸设置为 513 pixel \times 513 pixel,批处理数设置为 4,迭代次数设置为 300000。本文样本数据存在数据不平衡现象,在模型训练之前,统计了样本中各类标线所占像素数,并依据各类像素比例修改各分类在训练时的权重,以便获得较好的训练结果。

使用训练好的模型对验证集中的 9717 幅强度特征图像进行语义分割(部分结果如图 5 所示),并评定分类精度,精度评定结果如表 1 所示。采用像

素精度来表征每类标线的分类精度,即标记正确的像素占总像素的比例。采用均交并比(M_{IoU})^[22]来表征总体分类精度。均交并比为语义分割的标准度量,其计算两个集合的交集和并集之比,这两个集合为真实值和预测值,这个比例可以变形为真正的数量与真正、假负、假正(并集)数量之和的比值,计算公式如下

$$M_{IoU} = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}}, \quad (4)$$

式中: k 为种类数; p_{ij} 为属于类 i 但被预测为类 j 的像素数量,即 p_{ij} 为假正的数量; p_{ii} 为真正的数量; p_{ji} 为假负的数量。

表 1 自动提取与分类精度

Table 1 Accuracy of automatic extraction and classification

Classification	Accuracy / %
Mesh	88.17
Sidewalk	94.34
Entrance	86.51
Arrow	90.83
Deceleration vertical	81.47
Deceleration horizontal	76.36
Mark	77.62
Longsolid	95.73
Dotted	91.67
Transverse	92.35
M_{IoU}	85.47

由验证结果可以看出,自动提取与分类整体效果较好,但也存在一些漏分、错分现象。此外,标记和横纵向减速带的分类精度相对较低,长实线和人行道的分类精度相对较高,这主要与样本数量有关,标记和横纵向减速带的样本数量较少,导致模型训练结果不理想,从而影响验证精度。对于验证集,均交并比达到了 85.47%,证明基于深度学习的道路标线自动提取与分类方法可行且有效。

将本方法与文献[2]、[13]和[23]提出的方法进行道路标线提取与分类对比实验,实验数据为验证集 9717 幅强度特征图像,分别从精度、完整度和得分 F_{score} 三方面进行评定。精度、完整度和 F_{score} 的计算公式分别为

$$R_{Precision} = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (5)$$

$$R_{Completeness} = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (6)$$

$$F_{score} = \frac{2 \times R_{Precision} \times R_{Completeness}}{R_{Precision} + R_{Completeness}}, \quad (7)$$

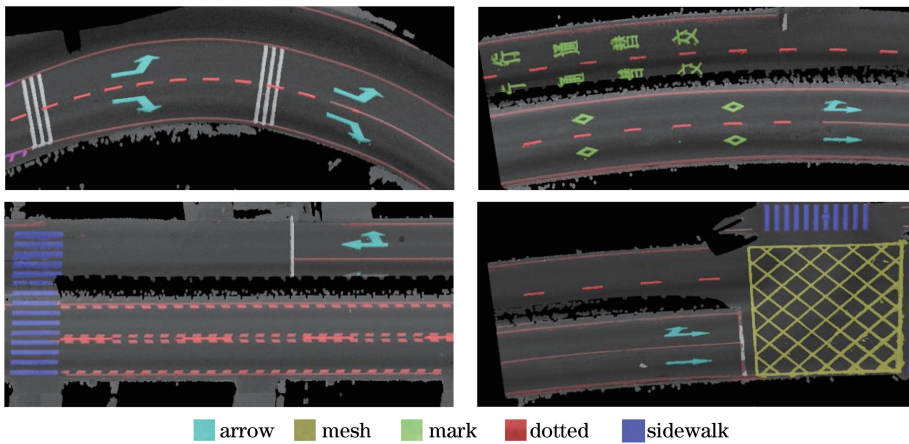


图 5 验证结果

Fig. 5 Validation results

式中： N_{TP} 、 N_{FP} 和 N_{FN} 分别为真正、假正和假负的数量； $R_{Precision}$ 为精度； $R_{Completeness}$ 为完整度。本方法与其他方法的对比结果如表 2 所示。

表 2 不同方法的对比

Table 2 Comparison of different methods

Method	$R_{Precision}/\%$	$R_{Completeness}/\%$	$F_{score}/\%$
Ref.[2]	77.03	53.79	63.34
Ref.[13]	93.27	73.86	82.44
Ref.[23]	74.29	66.53	70.20
Proposed	92.59	87.84	90.15

从表 2 可以看出：文献[2]和文献[23]提出的方法在实验数据上的精度和完整度都相对较低，导致 F_{score} 值也不理想；文献[13]提出的方法获得了 93.27% 的高精度，但完整度仅为 73.86%，最终 F_{score} 值为 82.44%；本方法在精度方面相较于文献

[13]提出的方法略低，为 92.59%，但是完整度和 F_{score} 值分别达到了 87.84% 和 90.15%，整体效果为 4 种方法中最优的。此外，文献[2]提出的方法仅对道路标线进行了提取，并未进一步对标线进行分类；文献[13]和文献[23]提出的方法都将提取与分类分步进行，且需要人为定义标线特征，并根据经验定义不同种类；而本文方法仅需对样本进行标记，通过深度学习网络模型进行训练，自主学习道路标线的特征，能够更丰富地刻画数据的内在信息，自动进行道路标线的提取与分类，减小人为因素的影响。

为实现道路标线的综合管理与维护，基于自动提取与分类结果，本文利用点云聚类分割算法实现了道路标识线点云的对象化，并针对不同类型的标线设计不同的矢量化方案，实现道路标线的矢量化，效果如图 6 所示。




图 6 标线矢量化。(a)分类结果；(b)聚类；(c)矢量化

Fig. 6 Road marking vectorization. (a) Classification results; (b) clustering; (c) vectorization

5 结 论

针对传统道路标线提取方法的局限性，采用车载移动测量系统采集激光点云数据，通过移动窗口法结合相邻扫描线拓扑关系获取地面点云，并生成

强度图像，基于深度学习实现道路标线的自动提取与分类，并利用 KD 树聚类分割算法结合矢量化方案实现道路标线的矢量化。通过对实际数据进行验证分析后可知，使用该方法进行自动提取与分类的单类最高精度可达到 95.73%，全类均交并比达

到 85.47%，自动提取与分类的总体精度和 F_{score} 分别达到 92.59% 和 90.15%。该方法提供了一种道路标线自动提取与分类的新思路，将推动道路标线获取与管理的智能化趋势。尽管该方法得到了较好的实验结果，但还有进一步改进与提高的空间，下一步将在以下几个方面进行探索：1) 为进一步提高分类的准确性，可以探索将道路标线的分类进一步细化，目前正尝试进行 19 类道路标线的自动提取与分类；2) 为进一步提高深度学习的运算速度，可通过多图形处理器 (GPU) 并行运算和云计算提升运算性能；3) 为实现二维分类结果到三维空间的转换，探索自动三维矢量转换算法，实现道路标线提取、分类和矢量化的一体化自动处理。

参 考 文 献

- [1] Peng J F. Study on automated extraction methods of highway elements from mobile lidar point clouds[D]. Beijing: Beijing University of Civil Engineering and Architecture, 2017: 38-41.
彭江帆. 基于车载激光扫描数据的高速公路道路要素提取方法研究[D]. 北京: 北京建筑大学, 2017: 38-41.
- [2] Yan L, Li Z. Road marking extraction from mobile LiDAR data[J]. Remote Sensing Information, 2018, 33(1): 1-6.
闫利, 李赞. 车载激光点云道路标线提取方法[J]. 遥感信息, 2018, 33(1): 1-6.
- [3] Li C, Creusen I, Hazelhoff L, *et al.* Detection and recognition of road markings in panoramic images [M] // Jawahar C, Shan S. Computer vision-ACCV 2014 workshops. Lecture notes in computer science Cham: Springer, 2015, 9009: 448-458.
- [4] Foucher P, Sebsadji Y, Tarel J P, *et al.* Detection and recognition of urban road markings using images [C] // 2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC), October 5-7, 2011, Washington, DC, USA. New York: IEEE, 2011: 12385335.
- [5] McCall J C, Trivedi M M. Video-based lane estimation and tracking for driver assistance: survey, system, and evaluation[J]. IEEE Transactions on Intelligent Transportation Systems, 2006, 7(1): 20-37.
- [6] Yang M M, Wan Y C, Liu X L, *et al.* Rapid automatic location and extraction for manhole covers based on ground mobile mapping system[J]. Chinese Journal of Lasers, 2018, 45(8): 0804001.
杨蒙蒙, 万幼川, 刘先林, 等. 基于地面移动测量系统的井盖快速自动定位与提取方法的研究[J]. 中国激光, 2018, 45(8): 0804001.
- [7] Guan H Y, Li J, Yu Y T, *et al.* Using mobile laser scanning data for automated extraction of road markings[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 87: 93-107.
- [8] Kumar P, McElhinney C P, Lewis P, *et al.* Automated road markings extraction from mobile laser scanning data [J]. International Journal of Applied Earth Observation and Geoinformation, 2014, 32: 125-137.
- [9] Holgado-Barco A, Riveiro B, González-Aguilera D, *et al.* Automatic inventory of road cross-sections from mobile laser scanning system [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(1): 3-17.
- [10] Chen G B, Gao Z H, He L. Step-by-step automatic calibration algorithm for exterior parameters of 3D lidar mounted on vehicle [J]. Chinese Journal of Lasers, 2017, 44(10): 1010004.
陈贵宾, 高振海, 何磊. 车载三维激光雷达外参数的分步自动标定算法[J]. 中国激光, 2017, 44(10): 1010004.
- [11] Fang L N. Automated extraction of road geometric features from mobile laser scanning point clouds[D]. Wuhan: Wuhan University, 2014: 52-66.
方莉娜. 车载激光点云中道路环境几何特征提取[D]. 武汉: 武汉大学, 2014: 52-66.
- [12] Yan L, Liu H, Tan J X, *et al.* Scan line based road marking extraction from mobile LiDAR point clouds [J]. Sensors, 2016, 16(6): 903.
- [13] Soilán M, Riveiro B, Martínez-Sánchez J, *et al.* Segmentation and classification of road markings using MLS data [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2017, 123: 94-103.
- [14] Goodfellow I, Bengio Y, Courville A. Deep learning [M]. Zhao S J, Li J, Fu T F, *et al.*, Transl. Beijing: Posts & Telecom Press, 2017: 1-15.
Ian Goodfellow, Yoshua Bengio, Aaron Courville. 深度学习[M]. 赵申剑, 黎君, 符天凡, 等, 译. 北京: 人民邮电出版社, 2017: 1-15.
- [15] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [16] Hu F, Xia G S, Hu J W, *et al.* Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery[J]. Remote Sensing, 2015, 7(11): 14680-14707.
- [17] Wen C L, Sun X T, Li J, *et al.* A deep learning framework for road marking extraction, classification and completion from mobile laser scanning point

- clouds [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 147: 178-192.
- [18] Yang M M, Wan Y C, Liu X L, *et al.* Laser data based automatic recognition and maintenance of road markings from MLS system [J]. Optics & Laser Technology, 2018, 107: 192-203.
- [19] Chen L C, Zhu Y K, Papandreou G, *et al.* Encoder-decoder with atrous separable convolution for semantic image segmentation [M] // Ferrari V, Hebert M, Sminchisescu C, *et al.* Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11211: 833-851.
- [20] Chen L C, Papandreou G, Kokkinos I, *et al.* DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40 (4): 834-848.
- [21] Gao L, Xie J, Cao T Z. An improved K-means clustering algorithm with high efficiency based on theKd tree [J]. Computing Technology and Automation, 2015, 34(4): 69-74.
高亮, 谢健, 曹天泽. 基于 Kd 树改进的高效 K-means 聚类算法 [J]. 计算技术与自动化, 2015, 34 (4): 69-74.
- [22] Garcia-Garcia A, Orts-Escolano S, Oprea S, *et al.* A review on deep learning techniques applied to semantic segmentation[J/OL]. (2017-04-22) [2017-04-22]. <https://arxiv.org/abs/1704.06857>.
- [23] Cheng M, Zhang H C, Wang C, *et al.* Extraction and classification of road markings using mobile laser scanning point clouds [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(3): 1182-1196.